



**ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU**  
**ŠUMARSKI ODSJEK**

**SVEUČILIŠNI DIPLOMSKI STUDIJ**  
**UZGAJANJE I UREĐIVANJE ŠUMA S LOVNIM GOSPODARENJEM**  
**STIPAN ČUPIĆ**

**DENDROKRONOLOŠKA I DENDROKLIMATOLOŠKA**  
**ANALIZA STABALA HRASTA LUŽNJAKA (*Quercus robur***  
**L.) NA PODRUČJU PRAŠUME PRAŠNIK**  
**DIPLOMSKI RAD**

**ZAGREB, 2016.**



**ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU**  
**ŠUMARSKI ODSJEK**

**SVEUČILIŠNI DIPLOMSKI STUDIJ**  
**UZGAJANJE I UREĐIVANJE ŠUMA S LOVNIM GOSPODARENJEM**

**DENDROKRONOLOŠKA I DENDROKLIMATOLOŠKA ANALIZA**  
**STABALA HRASTA LUŽNJAKA (*Quercus robur* L.) NA PODRUČJU**  
**PRAŠUME PRAŠNIK**  
**DIPLOMSKI RAD**

Diplomski studij: Uzgajanje i uređivanje šuma s lovnim gospodarenjem

Predmet: Rast i prirast

Ispitno povjerenstvo: 1. izv. prof. dr. sc. Mario Božić

2. dr. sc. Ernest Goršić

3. doc. dr. sc. Stjepan Mikac

Student: Univ. bacc. ing. silv. Stipan Čupić

JMBAG: 0068215010

Broj indeksa: 03482

Datum odobrenja teme: 11. travnja 2016.

Datum predaje rada: 7. rujna 2016.

Datum obrane rada: 9. rujna 2016.

**Zagreb, rujna, 2016.**

## DOKUMENTACIJSKA KARTICA

<b>NASLOV</b>	Dendrokronološka i dendroklimatološka analiza stabala hrasta lužnjaka ( <i>Quercus robur</i> L.) na području prašume Prašnik
<b>AUTOR</b>	Univ. bacc. ing. silv. Stipan Čupić
<b>ADRESA AUTORA</b>	Ulica Ivana Meštrovića 3, 22320 Drniš
<b>MJESTO IZRADE</b>	Svetošimunska ulica 25, 10 000 Zagreb
<b>VRSTA OBJAVE</b>	Diplomski rad
<b>MENTOR</b>	Prof. dr. sc. Mario Božić
<b>IZRADU RADA POMOGAO</b>	Dr. sc. Ernest Goršić
<b>GODINA OBJAVE</b>	2016.
<b>OBUJAM</b>	38 stranica + 26 slike, 61 navoda literature
<b>KLJUČNE RIJEČI</b>	dendroklimatologija, god, prirast, prašuma
<b>SAŽETAK</b>	<p>Kao dio međunarodnog projekta pod nazivom „<i>Mixed severity disturbances as drivers of structural variability and carbon dynamics at the stand and landscape levels</i>“, ovaj rad opisuje problematiku rasta i razvoja stabala hrasta lužnjaka (<i>Quercus robur</i> L.) na području prašume Prašnik. Nastoji se objasniti povezanost različitih stanišnih čimbenika promatrajući promjene u priraštanju godova. U radu se koriste i opisuju koncept i metodologija dendroklimatološkog istraživanja uz kratak pregled razvoja dendrokronologije kroz povijest te utjecaj klimatskih čimbenika na varijabilnost strukturnih i anatomskih elemenata, i to ponajprije utjecaj temperature i oborina na debljinski prirast stabala hrasta lužnjaka.</p> <p>Korištenjem dendroklimatološke metodologije i tehnike unakrsnog datiranja (<i>cross-datinga</i>), razvijena je osnovna referentna kronologija u duljini od 270 godina od 42 uzorka hrasta lužnjaka, sakupljenih u prašumi Prašnik 2015. godine. Sekundarnom analizom unakrsnog datiranja u COFECHA-i potvrdila se kvaliteta izmjere i svakom se godu pridružila stvarna godina njegovog nastanka. U ARSTAN programu izrađene su referentne kronologije (osnovna i rezidualna) i dobivena je statistička potvrda jačine populacijskog signala iz EPS i <i>r-bar</i> statističkih pokazatelja. S obzirom na razdoblje za koje su dostupni klimatski podaci (<i>Cru TS 3.23</i>) rezidualna kronologija izrađena u ARSTAN programu uspoređivana je s klimatskim podacima (temperaturom i oborinama) u razdoblju 1900.-2014. godine.</p>

## DOCUMENTATION CARD

<b>TITLE</b>	Dendrochronological and dendroclimatological tree analysis of pedunculate oak ( <i>Quercus robur</i> L.) in virgin forest of Prašnik
<b>AUTHOR</b>	Univ. bacc. ing. silv. Stipan Čupić
<b>AUTHOR ADRESS</b>	I. Meštrovića 3, 22320 Drniš
<b>SOURCE</b>	Svetošimunska 25, 10000 Zagreb
<b>TYPE OF ARTICLE</b>	Master Thesis
<b>MENTHOR</b>	Izv. prof. dr. sc. Mario Božić
<b>ACKNOWLEDGEMENT</b>	Dr. sc. Ernest Goršić
<b>YEAR OF RELEASE</b>	2016.
<b>VOLUME</b>	38 pages + 26 photos, 61 literature references
<b>KEYWORDS</b>	dendroclimatology, tree-rings, growth, climate change, old-growth forest
<b>SUMMARY</b>	<p>As part of an international project <i>Mixed severity disturbances as drivers of structural variability and carbon dynamics at the stand and landscape levels</i>, this thesis describes the problematics of growth and development of pedunculate oak (<i>Quercus robur</i> L. in virgin forest (old-growth forest, rainforest) of <i>Prašnik</i>. The thesis tries to describe the connection of tree-ring growth with habitat factors (temperature, precipitation). The concept and history of dendrochronology is described as well. Using the methodology of dendroclimatology, tree-rings are compared to climate data to investigate their variability and mutual connection.</p> <p>Tree-rings are cross-dated to confirm the dating of each tree-ring and reference chronologies of pedunculate oak are developed using <i>PAST</i> programing tool. Secondary statistical check of cross-dating and measurements is done in <i>COFECHA</i> program. Concerning the time period of available climate data (<i>CRU TS</i> – 1901.-2014.) and the replication issues (<i>EPS</i> and <i>r-bar</i>), mean residual reference chronology developed in <i>ARSTAN</i> program is compared to climate data (temperature and precipitation) in a time period of the last 114 years.</p> <p>Response function analysis shows negative correlation of temperature response of tree-rings in April and July for pedunculate oak, while showing positive correlation with precipitation in period from Januar until April, meaning the high temperatures of April and July are decreasing diametar growth, while high levels of precipitation in first four months of the year are increasing it.</p>

## SADRŽAJ RADA

<b>POPIS SLIKA</b> .....	<b>I</b>
<b>PREDGOVOR I ZAHVALE</b> .....	<b>II</b>
<b>1. UVOD</b> .....	<b>1</b>
1.1. Prašuma Prašnik te ukratko o pedološkim značajkama .....	1
1.2. Ukratko o dosadašnjim istraživanjima hrasta lužnjaka .....	6
1.3. Općenito o dendrokronologiji .....	10
<b>2. OPĆI CILJEVI RADA</b> .....	<b>15</b>
<b>3. MATERIJALI I METODE RADA</b> .....	<b>15</b>
3.1. TERENSKI RAD .....	15
3.1.1. Odabir lokacije .....	15
3.1.2. Metodologija bušenja i oprema .....	16
3.2. LABORATORIJSKI RAD .....	18
3.2.1. Priprema uzoraka za mjerenje .....	19
3.2.2. Mjerenje uzoraka .....	19
3.2.3. Unakrsno datiranje ( <i>cross-dating</i> ) .....	22
3.2.4. Statistička analiza unakrsnog datiranja .....	23
<b>4. REZULTATI I RASPRAVA</b> .....	<b>25</b>
4.1. Statistička provjera međusobne podudarnosti uzoraka u COFECHA-i.....	25
4.2. ARSTAN – veličina uzoraka, EPS i <i>RUNNING R-BAR</i> .....	27
4.3. Klimatski odziv hrasta lužnjaka prema temperaturi i oborinama .....	32
<b>5. ZAKLJUČAK</b> .....	<b>37</b>
<b>6. LITERATURA</b> .....	<b>38</b>

## POPIS SLIKA

Slika 1.1 Geografska lokacija prašume Prašnik.....	2
Slika 1.2 Pogled u sastojinu prašume Prašnik.....	3
Slika 1.3 Karta staništa – područje rijeke Save.....	4
Slika 1.4 Pedološka mapa istočne Hrvatske sa definiranim tipovima tla za Prašnik.....	5
Slika 1.5 Područje rasprostranjenja hrasta lužnjaka ( <i>Quercus robur</i> L.) u Europi.....	6
Slika 1.6 Rasprostranjenost hrasta lužnjaka ( <i>Quercus robur</i> L.) u Hrvatskoj .....	8
Slika 1.7 Shematski prikaz stvaranja referentnih dendrokronoloških nizova.....	11
Slika 1.8 Prikaz trenda porasta prosječne temperature zraka u posljednjih 150 godina .....	13
Slika 3.1 Prikaz metodologije odabira ploha i odabira uzorkovanja stabala.....	16
Slika 3.2 Shema ubušivanja borera „Presslerovog svrdla” u drvo .....	17
Slika 3.3 Razlika između Presslerovog svrdla proizvođača Suunto (dolje) te Haglof proizvođača (gore) .....	18
Slika 3.4 Vidljivost godova nakon brušenja te obrade brusnim papirom .....	19
Slika 3.5 Prikaz načina izmjere godova: ŠG – širina goda, RD – širina ranog drva, KD – širina kasnog drva .....	20
Slika 3.6 Mjerni stol Lintab 6 i stereo lupa priključeni na računalo.....	21
Slika 3.7 Tablica za upisivanje podataka o stablu koje se mjeri. ....	21
Slika 3.8 Prikaz postavljanja mjerne linije na početak goda.....	22
Slika 4.1 Pregled osnovnih parametara COFECHA analize (COFECHA) .....	25
Slika 4.2 Prikaz korelacije 50-godišnjih segmenata sa referentnom kronologijom (COFECHA) .....	26
Slika 4.3 Primjer uzorka s uraslom granom .....	27
Slika 4.4 Prikaz izjednačene krivulje prirasta.....	28
Slika 4.5 Prikaz osnovnog dendrokronološkog niza (gore), rezidualnog kronološkog niza (sredina) i veličine uzorka (dno) za lokaciju prašume Prašnik .....	29
Slika 4.6 Grafički prikaz rbar-a (gore) i EPS (dolje) za Prašnik.....	30
Slika 4.7 Grafički prikaz rbar-a (gore) i EPS (dolje) pokazatelja statističke analize u rezidualnoj kronologiji (ARSTAN).....	31
Slika 4.8 Prikaz koeficijenata korelacije prirasta i temperature .....	32
Slika 4.9 Prikaz koeficijenata korelacije prirasta i oborina .....	33
Slika 4.10 Usporedba oborina i temperatura: Vinkovci (gore) i Nova Gradiška (dolje) .....	35



## PREDGOVOR I ZAHVALE

Ovaj rad izrađen je na Zavodu za izmjeru i uređivanje šuma Šumarskog fakulteta Sveučilišta u Zagrebu kao dio projekta pod nazivom "*Mixed severity disturbances as drivers of structural variability and carbon dynamics at the stand and landscape levels*" (Ozbiljnost različitih poremećaja kao faktora strukturalne varijabilnosti i dinamike ugljika u sastojini i na razini okoliša).

Želio bih zahvaliti dr. sc. Ernestu Goršiću na pruženoj pomoći prilikom izrade ovoga rada te na savjetima kojima je doprinio njegovom poboljšanju.

Također, želio bih se zahvaliti prof. dr. sc. Mariu Božiću zbog prihvaćanja mentorstva i stavljanja na raspolaganje za bilo kakve konzultacije te savjete.

Hvala svim kolegama sa Czech University of Life Science Prague koji su me uveli u znanstveno područje dendrokronologije, a naročito dr. sc. Miroslavu Svobodi te dipl. ing. silv. Lenki Matejů.

Hvala doc. dr. sc. Stjepanu Mikcu na pozivu za sudjelovanje na terenskom radu na Velebitu i Plitvičkim jezerima u rujnu 2015. godine.

Također, hvala svim mojim prijateljima i obitelji koji su mi uvijek bili moralna potpora bez obzira gdje sam se nalazio.

Ovaj rad pomogla je financirati „Hrvatska zaklada za znanost” projektom CroFEM (IP-2014-648 09-1834).



# 1. UVOD

## 1.1. Prašuma Prašnik te ukratko o pedološkim značajkama

Stara šuma ili prašuma je tip šume koja se od svog nastanka razvijala uz malo ili bez ikakvog direktnog utjecaja čovjeka. One koje su bile pod određenim utjecajem čovjeka nazivamo sekundarne prašume, a one koje su nastale većinskim djelovanjem prirode nazivamo primarne prašume. Dakle, primarna prašuma je šuma na koju čovjek nije nikada direktno utjecao, dok je sekundarna prašuma nekada bila gospodarska šuma koju se izuzelo iz gospodarenja te prepustilo samoregulaciji. S vremenom takva šuma svojim najbitnijim strukturnim obilježjima postaje slična pravoj prašumi. Ne možemo govoriti o isključivom djelovanju prirode iz razloga što čovjek djeluje kroz zagađenje zraka, vode, meliorativne zahvate, itd. (Anić, 2004.)

Po geografsko-klimatskim karakteristikama, prašume dijelimo na nekoliko vrsta. One osnovne i najpoznatije su tropske kišne šume u tropskim područjima. Najznačajnija je Amazonija koja je veličine Europe i proizvodi 40% sveukupnog kisika na Zemlji te je opravdano dobila nadimak „zelena pluća Svijeta“. Također razlikujemo i skandinavske, europske te prašume umjerenih zona.

U Hrvatskoj imamo zavidan broj prašuma ukupne površine 859,95 ha, a kojih se ponajviše nalazi u dinarskom dijelu, dok su se dvije smjestile u panonskom dijelu Hrvatske. Jedne od najznačajnijih su Ramino korito, Čorkova uvala, Muški bunar, Bijele i Samarske stijene te Prašnik (Klepac, 1996).



Slika 1.1 Geografska lokacija prašume Prašnik  
(Mesić Kiš i sur., 2016)

Prašnik je jedinstvena sekundarna prašuma u novogradiškoj Posavini blizu Okučana. U njoj se nalaze posljednji ostaci slavonske prašume hrasta lužnjaka koja je pokrivala nizinski dio Panonije između Save i Drave. Odjel 7a iz redovnog je gospodarenja izlučen 1928. godine s površinom od 53,35 ha, a nalazi se na približno 96 m nadmorske visine. Njezinoj očuvanosti doprinijela je i okolnost Domovinskog rata jer je sve donedavno prašuma bila minirana, a tako i nedostupna za šumare, znanstvenike i posjetitelje. Njezino relativno nedavno razminiranje omogućilo je njezinu dostupnost i korištenje u znanstvene, edukativne i turističke svrhe, te samu izradu ovoga rada. Predio je 1965. godine proglašen specijalnim rezervatom šumske vegetacije što znači da je to područje u kojem je osobito izražen jedan ili više elemenata prirode, a osobitog je značenja i namjene.



Slika 1.2 Pogled u sastojinu prašume Prašnik

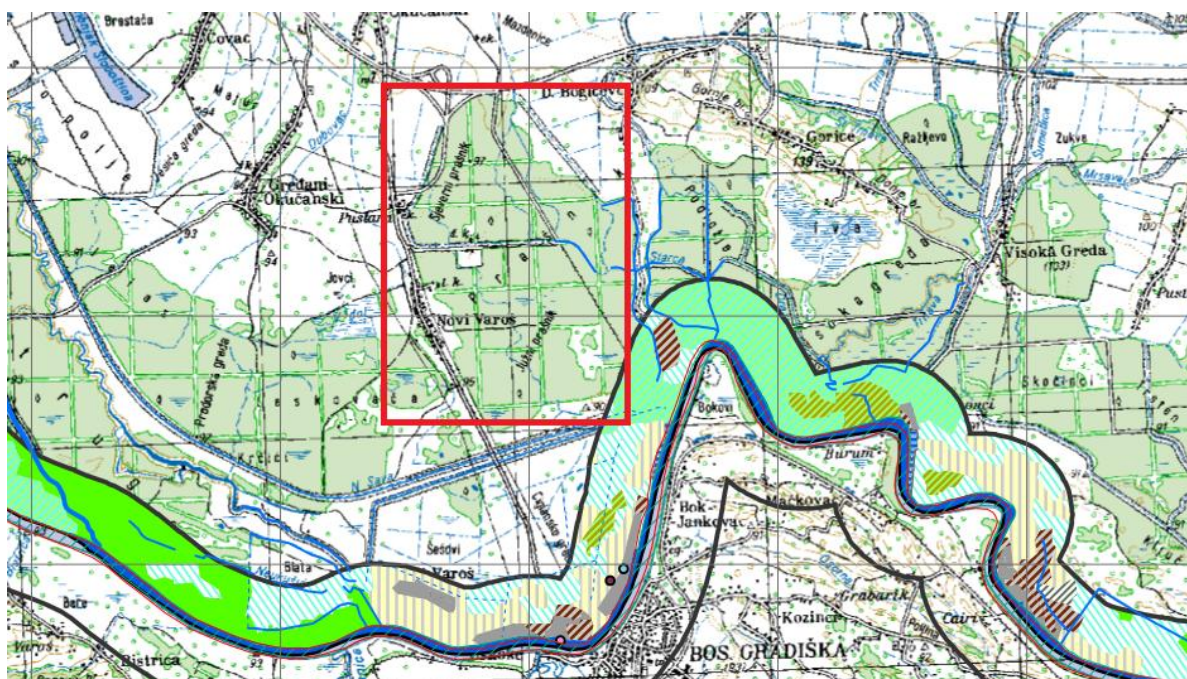
([http://www.novagra.hr/index.php?option=com\\_content&view=article&id=505:pranik-imuki%20bunar-neotkriveni-rezervati-umske-vegetacije&catid=70:turizamugostiteljstvo&Itemid=44](http://www.novagra.hr/index.php?option=com_content&view=article&id=505:pranik-imuki%20bunar-neotkriveni-rezervati-umske-vegetacije&catid=70:turizamugostiteljstvo&Itemid=44))

Ukupna drvena masa specijalnog rezervata šumske vegetacije je 33 802 m<sup>3</sup>. S fitocenološkog gledišta tu su zastupljene dvije šumske zajednice: tipična šuma hrasta lužnjaka i običnog graba ili *Carpino betuli* - *Quercetum roboris typicum* (Rauš, 1971.) te šuma hrasta lužnjaka sa velikom žutilovkom i rastavljenim šašem ili *Genisto elatae* - *Quercetum roboris caricetosum remotae* (Horvat, 1938).

Starost većine hrastovih stabala iznosi 250-300 godina. Dosežu prsni promjer preko 200cm te visine iznad 40m. Prilikom izmjere 1954. godine bilo je ukupno 1560 primjeraka starih hrastova, dok ih je 1974. godine ostalo 1487 s totalnom drvnom masom od oko 26 600 m<sup>3</sup>. Pojedini primjerci imaju drvnu masu oko 50m<sup>3</sup> (Rauš i sur., 1979).



Važno je napomenuti da je za održanje ovog ekosustava iznimno važan godišnji poplavni period uzrokovan izlivanjem rijeke Save. Iako Sava direktno ne naplavljuje Prašnik jer on ne spada u izravnu zonu poplavnih lužnjakovih šuma, lokalitet je ispresijecan manjim kanalima koji svakako vlaže okolno tlo. Također promjenom vodostaja Save, mijenja se i vodostaj kanala s kojom su oni povezani a samim tim i razina podzemne vode u okolnim sastojinama. U novije vrijeme nizinske šume hrasta lužnjaka ugrožene su snižavanjem razine podzemnih voda i melioracijom zemljišta (Tikvić i sur. 2008; Pilas, 2008).




Slika 1.3 Karta staništa – područje rijeke Save  
([www.mppi.hr](http://www.mppi.hr))

Protječući od svog izvora, rijeka Sava dotiče se raznih sedimenata i sedimentnih stijena koje su uglavnom sastavljene od mezozoičkih vapnenaca i dolomita te od paleozoičkih metamorfnih stijena i klastita te paleogenih klastita (Buser i sur., 1989). Područje prašume Prašnik prekriveno je debelim aluvijalnim sedimentima koji leže preko tercijarnih konglomerata, vapnenaca, lapora, pjesaka i gline (Šikić i sur., 1979; Šparica i sur., 1984; Halamić i Miko, 2009). Prema Bogunović i sur. (1998) hidromorfna tla, kao što su fluvisol, glej te podzoluvisol, prevladavaju na području prašume Prašnik (vidi sliku 1.3). Prema pedološkoj karti za Republiku Hrvatsku i prema svjetskoj referentnoj osnovici za tlo (WRB) (Bogunović i sur., 1998), na

području sjevernog Prašnika zastupljen je pseudoglej, a istočni dio sjevernog Prašnika je pod euglejem. Južni dio Prašnika djelomično je prekriven hidromeliorativnim euglejem (humofluvisol, humoglej). Pseudoglej zauzima 10,5% ukupnog teritorija Hrvatske (Bašić, 2013; Halamić i Miko, 2009) i klasificiran je kao hidromorfno tlo koje se pretjerano vlaži oborinama, poplavama i podzemnim vodama, što je idealna vrsta tla za uspijevanje hrasta, vrste čiji je razvoj usko vezan i ovisi o vodi u tlu. Hidromorfna tla, koja dominiraju hrvatskim dijelom Panonske nizine

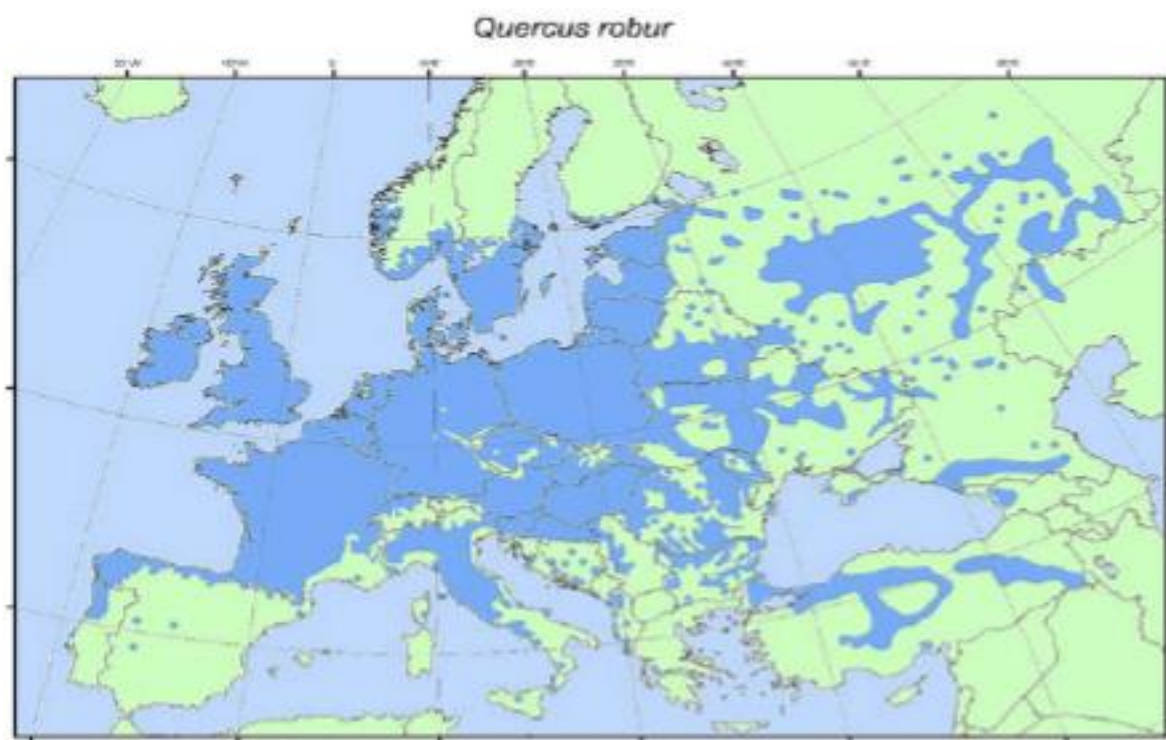
(Halamić i Miko, 2009; Husnjak, 2014) i širokim područjem uz panonske nizinske rijeke, prekrivena su aluvijalnim i euglejnim tlima koja su također prisutna na području sjevernog Prašnika. Tikvić i sur. (2008) samo potvrđuju većinskih pridolazak hrasta lužnjaka na područjima RH sa hidromorfnim tlima.



Slika 1.4 Pedološka mapa istočne Hrvatske sa definiranim tipovima tla za Prašnik (Mesić Kiš i sur., 2016)

## 1.2. Ukratko o dosadašnjim istraživanjima hrasta lužnjaka

Hrast lužnjak široko je rasprostranjena vrsta drveća na području Europe (vidi sliku 1.5). Zastupljen je od Skandinavije na sjeveru skroz do samog juga Italije, te od atlantske obale Pirinejskog poluotoka na zapadu do gorja Ural na samom istoku Europe.



Slika 1.5 Područje rasprostranjenja hrasta lužnjaka (*Quercus robur* L.) u Europi  
([www.euforgen.org/distribution\\_maps.html](http://www.euforgen.org/distribution_maps.html))

Hrast lužnjak je u prvim godinama svog života skiofit, a zatim naglo postaje heliofit (Anić i Mikac, 2008). Iako je rasprostranjen u jako širokom pojasu, za svoj razvoj lužnjak preferira područja s velikim amplitudama ljetnih i zimskih temperatura (Vajda, 1948). Isti autor navodi ukoliko promatramo tlo i klimu, hrast lužnjak spada u eurivalentne vrste, no ukoliko promatramo svaki čimbenik posebno širina ekološke valencije nije jednaka. Prema Dekaniću (1975), najveći limitirajući čimbenik koji utječe na rast hrasta lužnjaka je voda. Zbog velike količine vode koju transpirira za vrijeme




vegetacije, hrast lužnjak razvio je specifični korijenski sustav. U mladosti razvija žilu srčanicu i jako postrano korijenje koje prodire sve do razine podzemne vode (Goršić, 2013).

Lužnjak je plemenita i klimatogena vrsta koja je jako osjetljiva na promjenjene, a naročito pogoršane stanišne uvjete (tlo, klima) (Matić, 2008). Isti autor navodi kako je jedna od glavnih posljedica promjenjenih stanišnih uvjeta izostanak kvalitetnog prirasta. Tikvić i sur (2008) samo potvrđuju kako su promjene stabilnosti nizinskih šumskih ekosustava u RH uzrokovane promjenama dinamike poplavnih, površinskih i podzemnih voda, promjenom klimatskih prilika i drugim nepovoljnim čimbenicima. Pilas (2008) također navodi kako je jedan od najvećih preduvjeta za dugotrajan opstanak lužnjakovih šuma razina i dinamika podzemne vode koja približno odgovara hidrološkim uvjetima koji su vladali u vrijeme postankatih šuma.

Prema Čavloviću i sur. (2006) lužnjakove sastojine koje imaju narušenu strukturu su jako niske razine iskorištenosti potencijalne proizvodnosti. Ta narušena struktura velikim dijelom proizlazi iz ranije navedenih promjena u tlu i klimi. Također, trenutno stanje strukture i kvalitete drvne zalihe i prirasta je značajno ispod moguće proizvodnosti šumskih staništa hrasta lužnjaka na prvom bonitetu. Božić i sur. (2006) istražujući utjecaj nekih čimbenika na prirast jelovih stabala navode kako povećanje gustoće sastojine te oštećenosti stabala (zdravstveno stanje) dovode do smanjenja prirasta pojedinačnih stabala. Vjerovatno to vrijedi i za hrast lužnjak.

Lužnjak dobro uspijeva na svježim i vlažnim staništima močvarnih tala riječnih dolina, a lošije na terenima izloženim dugotrajnoj stagnirajućoj vodi jer smanjena mikrobiološka aktivnost u tlu, uzokovana hipoksijom, negativno utječe na opskrbu stabala dušikom (Dekanić, 1962; Mayer, 1996). Osim široke geografske rasprostranjenosti, stabla hrasta lužnjaka mogu dosegnuti duboku starost. U Hrvatskoj ta starost u prosjeku iznosi od 250 do 300 godina. Pri tome je bitno napomenuti da takva stabla najčešće više nisu komercijalno iskoristiva zbog oštećenja uzrokovanih bolestima i štetnicima. Prema pravilniku o uređivanju šuma, minimalna dužina ophodnje lužnjakovih sastojina u Hrvatskoj iznosi 140 godina i to je dob u kojoj stabla još pokazuju dobru vitalnost i visoki postotak ranije spomenute iskoristivosti sortimenata. Navedena duljina ophodnje najčešće se primjenjuje i u praksi. U Republici Hrvatskoj hrast lužnjak jedna je od najvrjednijih vrsta, kako od

komercijalnog, tako i od ekološkog značaja. Lužnjakove sastojine u RH zauzimaju 210 000 ha, što je 10% ukupne površine šuma RH.



Slika 1.6 Rasprostranjenost hrasta lužnjaka (*Quercus robur* L.) u Hrvatskoj  
(preuzeto iz Trinajstić, 1996)

Šumske zajednice – slavonska šuma hrasta lužnjaka i šuma hrasta lužnjaka sa običnim grabom smjenjuju se u svom arealu. Njihov pridolazak je najviše utjecan stupnjem vlažnosti staništa (blizina rijeke, vrsta tla, količina oborina, antropogeni utjecaji itd.) i reljefom (Prpić 1972). Isti autor navodi: „prostire se od Kupčine, dolinom Kupe nizvodno od Karlovca, dolinom Save od granice sa Slovenijom do šumskog bazena Spačva, Podravinom od granice s Mađarskom do Iloka“, pritom milseći na hrast lužnjak.

S obzirom na svoj ekonomski značaj, debljinski prirast lužnjakovih sastojina od velike je važnosti za hrvatsko šumarstvo (Goršić, 2013). Prirast sastojina ili samih stabala hrasta lužnjaka rezultat je djelovanja mnogih pojedinačnih i sinergijskih



čimbenika (Goršić, 2013). Prema Matiću (2000) podzemna voda je najbitniji stanišni čimbenik za pravilan razvoj lužnjakovih sastojina. Prpić (1996) ukazuje da je hrast lužnjak jako osjetljiv na ljetnju sušu, iako je kao vrsta eurivalentan glede klimatskih zahtjeva. Također, mnoga su istraživanja pokazala da nagle promjene u stanišnim prilikama dovode do fiziološkog slabljenja stabala hrasta lužnjaka, te samim time do pada debljinskog prirasta.

Zahvat prorede pozitivno utječe na prirast hrastovih stabala što je naročito izraženo u mlađim i srednjodobnim sastojinama (Milković, 1998; Goršić, 2013). Prema Bobincu i Andraševu (2009), prorede u mlađim sastojinama hrasta lužnjaka mogu povećati debljinski prirast i preko 30%. Razni insekti mogu negativno djelovati na debljinski prirast stabla hrasta lužnjaka, primjerice napad gubara može prouzročiti pad volumena za oko 30% u godini napada (Klepac, 1959). Ne manje značajna je hrastova pepelnica koja se nerijetko pojavljuje nakon golobresta gubara, a koja također usporava prirast hrastovih stabala. Na području Europe spominje se još od 1907., a Marçais i Desprez-Loustau (2012) navode da spada u jedne od najčešćih bolesti hrastova u Europi. U posljednje vrijeme, prilikom analize utjecaja pojedinih čimbenika na prirast stabla, teško je izostaviti utjecaj klimatskih promjena. Na znanstvenom skupu u Francuskoj znanstvenici su iznijeli podatak da će se temperatura na Zemlji do 2100. godine povećati za 4,5 do 5°C (Kajba, 2006). Isti autor navodi kako je hrast lužnjak svrstan u kategoriju onih vrsta koje ne bi bile značajno ugrožene navedenim klimatskim promjenama.

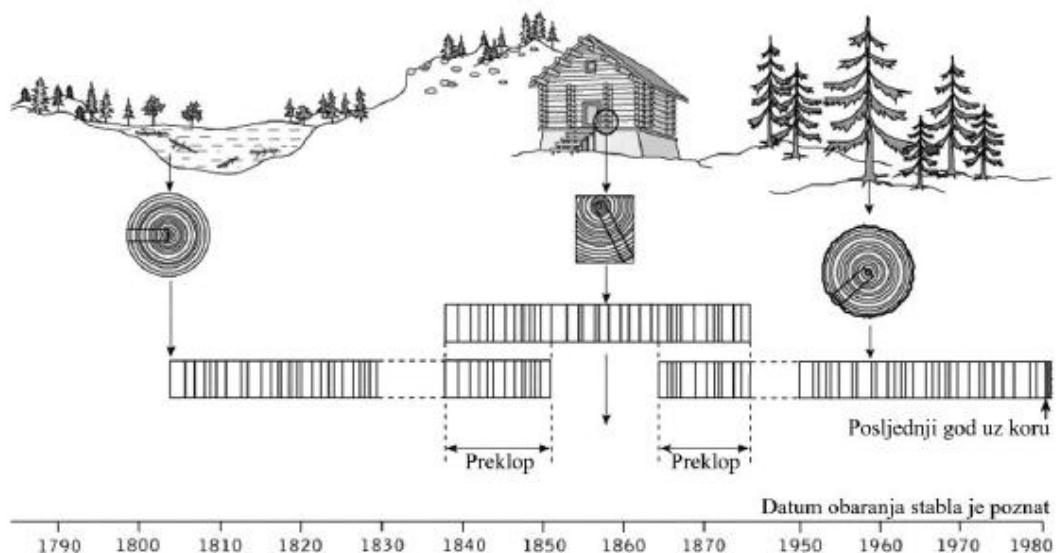
Kajba i Hrašovec (2008) navode iako je šumsko drveće u Europi adaptirano na nadolazeće klimatske promjene, one će znatno izmijeniti postojeće ekološke prilike a samim tim izložiti novim štetnicima i bolestima. Osim konstantnog porasta temperature, očekuje se i pojava sve ekstremnijih suša, poplava i požara, što će se jako negativno odraziti na šumske ekosustave (Pilas, 2008).

Prilikom istraživanja utjecaja klime na radijalni prirast hrasta lužnjaka, Lukić i sur. (2001) navode da su za dendroklimatološke analize najvažniji čimbenici temperatura zraka, količina oborina te relativna vlaga zraka.

### 1.3. Općenito o dendrokronologiji

Za bolje razumijevanje same analize klimatskih signala hrasta lužnjaka u prašumi Prašnik, potrebno je definirati određene znanstvene discipline (dendrokronologija, dendroklimatologija te dendrohidrologija), pojmove (god, debljinski i radijalni prirast) te metodologiju korištenu u dotičnom istraživanju.

U umjerenom klimatskom pojasu količinu godišnjeg radijalnog prirasta definiraju klimatski čimbenici (oborine, temperatura), a ekološki čimbenici (opskrba hranjivom, svjetlom i vodom), genetske predispozicije stabala, starost, stanje krošnje, razna oštećenja te uzgojni postupci utječu na prirast pojedinih stabla (Becker, 1991). Biološki čimbenici kao što su brštenja izazvana kukcima ili gljivične infekcije imaju veliki utjecaj na prirast stabla. Stoga je debljinski prirast stabla pod utjecajem stanišnih (ekoloških) i sastojinskih (strukturnih) datosti u kojima ono raste (Božić, 2003). Radijalni prirast stabla tijekom jedne vegetacijske periode naziva se god. Pošto je poprečni presjek stabla nesavršena kružna ploha, debljinski prirast stabla jednak je zbroju dvaju nasuprotnih radijalnih prirasta istoga (Goršić, 2013). U tropskim područjima pojava goda uvjetovana je stanišnim promjenama (poplave, suše) budući da u tom pojasu izostaje razdoblje zimskog mirovanja vegetacije kakvo postoji u umjerenom pojasu. Također, očitavanje, odnosno „brojanje“ godova stabala iz tropskih područja može biti prilično izazovno, a u nekim slučajevima gotovo i nemoguće. Dakle, pojava godova vezana je uz prostore umjerenog pojasa. Širinu godova možemo slobodno definirati i kao „zapisnik“ svih pozitivnih i negativnih promjena tijekom života pojedinog stabla unutar njegovog staništa. Starost stabla koje raste u umjerenom zoni može se utvrditi brojanjem godova na njegovom poprečnom presjeku. Važno je napomenuti da, ukoliko želimo znati stvarnu starost stabla, broju godova koje smo izbrojali, te koji ujedno predstavljaju i broj godina, trebamo dodati broj godina koliko je stablu trebalo da naraste do visine panja (Goršić, 2013). Manje poznata činjenica je da se uzorak širih i užih godova može usporediti s drugim stablima kako bi se utvrdila točna godina nastajanja goda. Datiranjem uzoraka drveta bavi se dendrokronologija.



Slika 1.7 Shematski prikaz stvaranja referentnih dendrokronoloških nizova.

([www.wissenschaft-online.de/abo/lexikon/biok/466](http://www.wissenschaft-online.de/abo/lexikon/biok/466))

Dendrokronologija je znanstvena disciplina koja uspoređuje širine godova u stablima metodom unakrsnog datiranja (*cross-dating*) (Goršić, 2013). Sama riječ potječe od starogrčkih riječi *dendron* što znači stablo te *chronos* što znači vrijeme. Ranije objašnjeni mehanizam debljinskog prirasta stabla omogućuje dendrokronolozima da kroz analizu godišnjeg prirasta stabala (god) te kroz mogućnost unakrsnog datiranja razviju dugačke i kvalitetne vremenske nizove godova za određeno područje (grupa stabala, ploha, sastojina, regija) sastavljene od potrebnog broja uzoraka stabala na temelju kojih se proučavaju i interpretiraju informacije iz proteklih ili sadašnjih okolišnih događaja i procesa. Unakrsno datiranje je temeljni princip dendrokronologije; tehnika koja osigurava da je svaki pojedini god dodjeljen točnoj kalendarskoj godini svoje formacije. To se postiže na način da se uspoređuje podudarnost širine godova među uzorcima koji su prikupljeni na istom lokalitetu te onima sa nekog drugog lokaliteta. Kada se određeni segment uklapa u kronologiju dužeg segmenta, usporedbom se točno određuje godina nastanka pojedinog goda. Na taj način moguće je odrediti točnu starost nekog drvenog fragmenta (slika 1.7).

S obzirom da su stabla u direktnoj međuovisnosti sa svojom okolinom, razvoj stabala predmet je utjecaja klime (varijabilnosti u temperaturi, oborinama, utjecaju vjetra, utjecaju leda, i sl.), s mogućnošću njezinog zapisivanja u strukturi godova. Upravo ti „zapisi” ili „žigovi” u obliku varijabilnosti u širini, gustoći ili strukturi godišnjih prstenova služe dendroklimatolozima za interpretaciju klimatske prošlosti, s ciljem shvaćanja sadašnjosti i donekle procjenjivanja klimatskih promjena te kako će one utjecati na prirašćivanje stabala.

Rezultat utjecaja limitirajućeg faktora (faktor koji je u prirodi najoskudniji te koji kontrolira rast), stimulirajućih faktora (npr. dostupnost vode i svjetla) te bioloških i fizioloških svojstava vrste je različita širina godova iz godine u godinu. Različiti stanišni čimbenici poput nadmorske visine, geomorfološke podloge, tla, ekspozicije, inklinacije, i sl. također utječu na širinu godova.

Kod četinjača, mnogo češće nego kod listača, nerijetko dolazi do stvaranja lažnih godova ili nepostojećih godova, što uvelike otežava datiranje individualnih uzoraka, no taj problem može se ukloniti pravilnom pripremom uzoraka za mjerenje i unakrsnim datiranjem većeg broja uzoraka s neke lokacije (princip replikacije). Kod ponekih uzoraka, broj godova koji nedostaju toliko je velik da uzorak nije dobar za analizu te se odbacuje.

Dendrokronologija svoje službene znanstvene korijene vuče iz SAD-a, točnije iz savezne države Arizone gdje je osnovan „Laboratorij za istraživanje godova”, radom američkog dendrokronologa A. E. Douglassa<sup>1</sup>, koji se s razlogom naziva „ocem dendrokronologije” (Webb, 1983). Dendrokronologija je kroz prošlost uglavnom korištena za intenzivno proučavanje utjecaja industrijskog onečišćenja okoliša, a njeni počeci u Europi naziru se početkom 19. stoljeća. Prije više od 100 godina, analiziranje godova koristilo se za prepoznavanje i kvantificiranje oštećenja šuma uzrokovano onečišćenjem zraka (Cook i Kairiukstis, 1990).


Danas, dendrokronologija svoju svrhu ispoljava u arheologiji, klimatologiji, ekologiji, geomorfologiji, kemiji, kriminalističkoj forenzici, povijesti i sl.

---

<sup>1</sup> A.E. Douglass – američki astronom koji je otkrićem korelacije između godova i ciklusa Sunčevih pjega, utemeljio znanstvenu disciplinu zvanu dendrokronologija. Ponajviše je zaslužan za usavršavanje metode unakrsnog datiranja (*crossdating*).

Dendroklimatologija spada samo u jedno od potencijalnih podpodručja za istraživanje klimatskih promjena u prošlosti unutar šire znanstvene discipline zvane paleoklimatologija, koja, osim godova, koristi zapise iz ledenih pokrivača, depozicije sedimenata, razvoja koralja i špiljskih ukrasnih stijena (poput stalaktita i stalagmita) za proučavanje klime.

Danas su klimatske promjene predmet mnogih istraživanja, budući da u kombinaciji s industrijalizacijom, urbanizacijom, nekontroliranim porastom stanovništva, oštećenjem ozonskog omotača i efektom staklenika imaju značajan utjecaj na stabilnost ekosustava koje ljudska vrsta nastanjuje te na samu kvalitetu života ljudi. Iako danas postoje oprečna mišljenja o klimatskim promjenama, činjenica je da smo u posljednjih 100 godina svjedoci sve učestalijih elementarnih nepogoda te zabilježenog trenda porasta prosječne godišnje temperature zraka. U posljednje vrijeme, sve je više znanstvenih radova posvećeno proučavanju klimatskih promjena koje su itekako prisutne, naročito u posljednjih nekoliko desetljeća. Iako danas postoje oprečne teorije o uzroku globalnog zatopljenja, ne možemo pobjeći od činjenice da je prosječna godišnja temperatura na Zemlji u konstantnom porastu (slika 1.8). Upravo zbog navedene činjenice, jako je važan znanstveni doprinos dendrokronologa za razumijevanje ekoloških promjena u prošlosti te na temelju njih predviđanje klimatskih promjena te njihov utjecaj na debljinski prirast sastojina i samih stabala.



Slika 1.8 Prikaz trenda porasta prosječne temperature zraka u posljednjih 150 godina  
(<http://www.cru.uea.ac.uk/>)

Dendroklimatološka istraživanja zasnivaju se na analizi vrijednosti indeksa (koji proizlaze iz širina godova) referentnih kronologija sa klimatskim podacima meteoroloških postaja koje su najrelevantnije proučavanim plohama (Evans i sur., 2006.).

Statističke analize u dendroklimatologiji, podrazumijevaju korištenje računalnih programa (*COFECHA*, *ARSTAN*, *R*) za provođenje standardizacijskih postupaka .

Namjera standardizacijskih postupaka je uklanjanje prirasnih trendova (trend rasta tj. maksimiziranje signala) te mogućnost usporedbe s klimatskim podacima. Korištenjem navedenih računalnih programa, statistički se analiziraju dobivene kronologije kroz manipulaciju signala. U literaturi (Biondi i Qedan, 2008) su predlagane razne tehnike za uklanjanje varijacija u prirastu individualnih stabala i osnovnoj kronologiji poput standardiziranja individualnih izvrtaka prije nego se uklope u glavnu (*master*) kronologiju ili u prošlosti vrlo često korištene tzv. negativne eksponencijalne krivulje (Fritts, 1969) koje prate model rasta stabala, ili danas često korištene fleksibilne kubne krivulje (*spline*), kao empirički model koji bolje izdvaja populacijski signal (Cook, 1985).

Dendrokronologija, kao znanstvena disciplina, sastoji se od poddisciplina koje imaju uži fokus istraživanja. Tako razlikujemo: dendroekologiju, dendroarheologiju, dendroklimatologiju, dendrogeomorfologiju te dendrokemiju. Također, navedene poddiscipline mogu se dalje granati na podpolja, pa je tako dendrohidrologija podpolje dendroklimatologije, a dendroseizmologija, dendroglaciologija i dendrovulkanologija podpolja su dendrogeomorfologije (Speer, 2010).

Analiza uzoraka sakupljenih godova može nam dati kratkoročnu i dugoročnu evidenciju klimatske varijabilnosti tijekom prošlosti za vrijeme života drveća. Parametri koji su najčešće promatrani u dendroklimatologiji su temperatura, oborine te suša, ali također mogu biti promatrani i godišnji broj oblačnih dana, relativna vlažnost zraka, jačina vjetra te svi ostali čimbenici koji mogu utjecati na proces rasta stabla. Upravo dendroklimatologija ima najviše doprinosa u ranije spomenutom proučavanju klimatskih promjena. Također, rekonstrukcijom vodostaja, bilo stajačice ili tekućice bavi se dendrohidrologija (Speer, 2010).

## 2. OPĆI CILJEVI RADA

Cilj ovog rada je dendrokronološki i dendroklimatološki analizirati klimatski odziv hrasta lužnjaka (*Quercus robur* L.) na području prašume Prašnik. Na temelju prikupljenih uzoraka hrasta lužnjaka, u radu se nastoji opisati i kvalitativno prikazati postupke datiranja godova pojedinih izvrtaka (uzoraka) stabala te razviti kvalitetnu i reprezentativnu kronologiju uzoraka s istraživanog područja. Ispitat će se značajnost utjecaja određenih klimatskih čimbenika (temperature i oborina) na prirast stabala hrasta lužnjaka te grafički prikazati međusobnu ovisnost između debljinskog prirasta i klimatskih vrijednosti.

## 3. MATERIJALI I METODE RADA


### 3.1. TERENSKI RAD

#### 3.1.1. Odabir lokacije

Na samom početku jako je važno detaljno isplanirati terenski rad te odabirati lokaciju uzorkovanja. Također, pažnju treba posvetiti samom odabiru uzoraka, dakle odabiru onih reprezentativnih s ciljem da se dobiju što bolji rezultati.

Unutar svake mreže poligona nasumično su odabrane tri točke iz kojih se po liniji i prema određenom azimutu u udaljenosti od 40 m na obje strane od poligone točke fiksiralo središte svake podplohe s prvom podplohom bližom sjeveru. Središta kružnih podploha su u pravilu bila postavljena u istoj liniji prema poligonoj točki, ukoliko su okolnosti na terenu to dopuštale.

Svaka podploha sastojala se od tri kruga različitog radijusa unutar kojih se određivao minimalni prsni promjer stabala biranih za vađenje izvrtaka. U prvom krugu, radijusa 8 m (200 m<sup>2</sup>), bušena su sva stabla minimalnog prsnog promjera od 6 cm, u drugom krugu, radijusa 17,84 m (1000 m<sup>2</sup>), stabla minimalnog promjera od 20 cm, a u trećem krugu, radijusa 21,85 m (1500 m<sup>2</sup>), birana su samo stabla minimalnog prsnog promjera od 60 cm (slika 3.1).




Slika 3.1 Prikaz metodologije odabira ploha i odabira uzorkovanja stabala (terenski obrazac)

### 3.1.2. Metodologija bušenja i oprema

Od opreme, na terenu su se koristili: mjerna vrpca, dugačka Presslerova svrdla s izvlakačem uzoraka („žlicom“), plastične cjevčice, tj. „slamke“ (za pohranu individualnih uzoraka) i tuba (za prijenos svih uzoraka), voodootporni crni marker za pravilno označavanje slamke s uzorkom (radi izbjegavanja miješanja istih), promjerka (izmjera prsnog promjera), odgovarajući formulari za evidenciju stabala te GPS uređaj.

Budući da prikupljanje izvrtaka spada u izrazito zahtjevan fizički rad, s ciljem manjeg umaranja, bušenje stabla vršilo se na prsnoj visini zbog najprirodnije pozicije ruku, ne dublje od 2/3 ukupnog promjera stabla. Nastojalo se uzeti uzorak koji prolazi kroz samo srce stabla te koji ne sadrži reakcijsko drvo (slika 3.2).





Slika 3.2 Shema ubušivanja borera „Presslerovog svrdla” u drvo  
(Speer, 2010)

Sa svakog stabla, nakon što je stablo izbušeno, vadila su se po dva uzorka (dva radijalna prirasta istog stabla) koja su se zajedno s odgovarajućim oznakama na papiriću umetala u plastične slamke, te se spremala u transportnu tubu s ostalim uzorcima. Također, nerijetko dolazi do oštećenja svrdla zbog samih dimenzija stabla i tvrdoće hrastova drveta. Preporučljivo je koristiti Presslerova svrdla finskog proizvođača Suunto jer je lakše vađenje borera iz drva a naročito prilikom dolaska do trulog dijela drva. Haglof nema dodatni navoj nakon proširivača te je spomenuto vađenje iz drva dosta zahtjevnije (vidi sliku 3.3).




Slika 3.3 Razlika između Presslerovog svrdla proizvođača Suunto (dolje) te Haglof proizvođača (gore)

### 3.2. LABORATORIJSKI RAD

Pri povratku s terena, uzorci su spremeni u hladnjak na konstantnoj temperaturi od oko 5°C gdje se skladište do daljnjeg korištenja. Za daljnju laboratorijsku obradu uzorci se bruse, dok su za analizu i finalno razvijanje kronologije zaslužni COFECHA i ARSTAN kompjutorski programi. Klimatski podaci preuzeti su s web stranice KNMI Climate Explorer koji osim pristupa klimatskim podacima u širokom vremenskom rasponu omogućuje korelacijsku i regresijsku analizu, izračun i analizu klimatskih ekstrema te mnoge druge informacije o klimi koje su nužne za dendroklimatološka istraživanja. Sve statistički analizirane podatke KNMI Climate Explorer preuzima sa mreže meteoroloških postaja (Trouet i van Oldenborgh, 2013).

### 3.2.1. Priprema uzoraka za mjerenje

Nakon što su se izvrtci osušili, neposredno prije same izmjere brušenjem su skidani slojevi drva. Razlog zašto se slojevi skidaju do određene dubine izvrtka je taj da se granice godova jasno vide, a uzorak bude dovoljno obrađen za lijepljenje u utor na drvenim pločicama. Pri tome treba obratiti pažnju da se uzorak u žljebu okrene tako da poprečni presjek bude vidljiv s gornje strane. Po potrebi, nakon lijepljenja brušenih uzoraka, na drvene pločice brusnim papirom ručno se dodatno polira njihova površina radi poboljšanja vidljivosti granica godova, a ako ni to nije dovoljno, vidljivost godova može se poboljšati stavljanjem obične školske krede na sam izvrtak.



Slika 3.4 Vidljivost godova nakon brušenja te obrade brusnim papirom  
(Goršić, 2013; Doktorski rad)

### 3.2.2. Mjerenje uzoraka


Izmjera širine godova provedena je na Šumarskom fakultetu Sveučilišta u Zagrebu, na Zavodu za izmjeru i uređivanje šuma. Za mjerenje širine godova korišten je mjerni stol Lintab 6 s programskim paketom TSAP-Win Scientific u kombinaciji sa stereo lupom Leica M50 (Slika 3.6). Širina godova mjerena je počevši od središta izvrtka (srži) u smjeru kore. Širina jednog goda podrazumijeva širinu kasnog i ranog drva, a vrijednost širine (u mm) koristi se dalje u analizi i izradi individualne kronologije.



Slika 3.5 Prikaz načina izmjere godova: ŠG – širina goda, RD – širina ranog drva, KD – širina kasnog drva  
(preuzeto od Goršić, 2013; Doktorski rad)

TSAP-Win programski paket nudi se u tri inačice: Basic, Professional i Scientific (Rinn, 2003). TSAP-Win Scientific inačica programa najnaprednija je i, osim mjerenja širina godova i jednostavne usporedbe uzoraka s grafičkim prikazom, omogućuje i zahtjevnije matematičke operacije i dendroekološke analize te njihov grafički prikaz. Na stereo lupi je korišten objektiva Leica Achromat 1x i okulari 10x. Preciznost mjerenja Lintaba 6 je 1/100 mm, a maksimalna širina (dužina) uzorka koji se može mjeriti je 56 cm. To je dovoljno za izmjeru radijusa većine stabala koja rastu na našim prostorima (Goršić, 2013).






Slika 3.6 Mjerni stol Lintab 6 i stereo lupa priključeni na računalo  
(preuzeto od Goršić, 2013; Doktorski rad)

Prije početka izmjere, u programu su za svaki pojedinačni uzorak (dva radijusa unutar stabla) uneseni podaci o vrsti stabla, lokaciji uzorkovanja, prsnom promjeru stabla, visini stabla i visini na kojoj je uzorak uzet (slika 3.7). To je bitno jer se na taj način kasnije može lako doći do podataka relevantnih za uzorkovano stablo (Goršić, 2013).

Dataset header												
Header	Location	Dates	Tree	Timber	Math	Images	Comments	Bibliography	Archeology	Geography	Forestry	User defined
Keycode	Project		Location		Species	Length	DateBegin	DateEnd				
						0	0	0				
Keycode:			Location:			Key number:						
Project:												
Species code:		Sp. name:			----							
Tree no.		Length:	0		Data type:		Dated:					
Radius no.		Pith:			Unit:		Date begin:	0				
Core no.		Sapwood:		rings	Series type:		Date end:	0				
Stem disk no.		Waldkante:			Series starts with:		Series ends with:					
Comment:												
<input type="button" value="OK"/> <input type="button" value="Cancel"/>												

Slika 3.7 Tablica za upisivanje podataka o stablu koje se mjeri.

Samo mjerenje vrši se na način da se uzorak koji se nalazi zalijepljen na daščici postavlja na mjereći stol te okreće njegovu ručicu (vidi sliku 3.6). Na taj način uzorak se pomiče ispod stereo lupe koja u jednom od okulara ima mjernu skalu. Nastoji se što preciznije poravnati mjernu liniju, koja se nalazi u sredini mjerne skale, s početkom goda (slika 3.8).



Slika 3.8 Prikaz postavljanja mjerne linije na početak goda  
(Preuzeto od Goršić, 2013; Doktorski rad)

### 3.2.3. Unakrsno datiranje (*cross-dating*)

Unakrsno datiranje je najosnovnija analizirajuća tehnika u dendrokronologiji. Osigurava da je svakom pojedinom godu dodana točna kalendarska godina njegove formacije. To se postiže usporedbom i uklapanjem godina, bilo sa uzorcima istog drveta i lokacije ili pak drvećem sa druge lokacije.

Unakrsno datiranje vršilo se pomoću PAST kompjuterskog programa koji omogućava prethodno spomenutu analizu i kontrolu kakvoće mjerenja svih uzoraka uz mogućnost dodavanja ili oduzimanja godina, kao i pregled međusobne podudarnosti uzoraka. Dakle, program korelira izmjerene segmente zasebnih serija godina u glavnu (master) kronologiju sastavljenu od preostalih serija godina sa istraživanog (ili nekog drugog) lokaliteta gdje su uzorci prikupljeni.

Nakon unakrsnog datiranja uzoraka pristupa se usporedbi dvaju krivulja. Ta se usporedba zasniva na računanju koeficienta korelacije svih mogućih pozicija preklapanja. GLK i TVBP su vrijednosti koje pokazuju kako dva uzorka odgovaraju jedan drugome u određenoj poziciji preklapanja.

GLK (*Gleichläufigkeit*) vrijednost je mjera sličnosti između dvije individualne kronologije bazirana na prvoj razlici između sukcesivnih godina (Schweingruber, 1988)., te statistički pokazatelj podudarnosti uzoraka inkorporiran u program PAST. Studentov t-test uspoređuje razlike između dvije kronologije, te je ujedno i statistička mjera za traženje podudarnosti kronologija.

TVBP vrijednost se koristi za uspoređivanje i unakrsno datiranje širina serija godina, što određuje stupanj korelacije među krivuljama.

Određeni broj uzoraka ne završava sa 2015. godinom, tj. datiran je na ranije godine, a glavni razlog tome je trulež na vanjskom dijelu stabla. To je uglavnom bio slučaj kod mrtvih stabala, koja su također uzimana u obzir za dotično istraživanje.

Takvi uzorci se datiraju na način da se njihova kronologija usporedi sa kronologijom ostalih uzoraka sa tog lokaliteta a koji su datirani do 2015. godine, te se traži godina u kojoj se ti uzorci najbolje preklapaju i gdje vrijednost korelacije odgovara.

#### **3.2.4. Statistička analiza unakrsnog datiranja**

Koncept standardizacije zasniva se na korištenju statističkih računalnih programa kojima se različiti tipovi krivulja podešavaju trendovima u godovima. Na taj način uklanjaju se razlike u prirastu između individualnih uzoraka te čimbenici varijabilnosti koji se smatraju "šumom" te produciraju srednju vrijednost uzoraka jednaku 0 (COFECHA) ili 1 (ARSTAN) (Holmes, 1983; Cook i Krusic, 2005).

COFECHA program nastao je krajem 70-ih godina prošlog stoljeća kad je Richard Holmes kreirao njegove algoritme koristeći tehnike korelacije. Navedeni program za analizu kvalitete unakrsnog datiranja često se koristi kao statistička dopuna vizualnoj provjeri sinkronosti izmjerenih podataka koja se koristi za izradu referentne (*master*) kronologije (Goršić, 2013). Nakon sekundarne vizualne provjere kvalitete unakrsnog datiranja, korištenjem COFECHA-e dobiva se statistička informacija o pouzdanosti

pravilnog unakrsnog datiranja svakog pojedinog uzorka u odnosu na referentnu kronologiju (Grissino-Mayer, 2001). Važno je naglasiti kako se referentna kronologija razvijena u COFECHA-i razlikuje od referentne kronologije koja će se koristiti za usporedbu s klimatskim podacima (Speer, 2010).

Detaljan opis korištenog programa i pojedinih funkcija nalazi se na stranici [www.ncdc.noaa.gov/paleo/treering/cofecha/userguide.html](http://www.ncdc.noaa.gov/paleo/treering/cofecha/userguide.html).

ARSTAN (*AutoRegressive STANdardization*) je program pomoću kojeg su se, koristeći različite tehnike uklanjanja trenda (standardizacije), uklonile one informacije koje za naše dendroklimatološko istraživanje predstavljale „šum“, a proizlaze iz utjecaja neklimatskih faktora, te se maksimizirao klimatski signal. ARSTAN je razvijen kako bi matematički standardizirao serije godina i minimalizirao autokorelacijsku komponentu u individualnim uzorcima (Cook i Holmes, 1986). Dakle, pomoću ARSTAN-a djelomično uklanjamo trend rasta stabla (Cook i Peters, 1997). U osnovnoj kronologiji sastavljenoj međusobnim preklapanjem tzv. „sirovih podataka“ (TRW) nalaze se klimatski i neklimatski trendovi (juvenilni rast, utjecaja strukturnih poremećaja u šumi, autokorelacije i sl.). Stoga pripremi osnovnih kronologija za klimatsko istraživanje nužno prethodi uklanjanje nepoželjnih trendova koristeći jednostavne determinističke modele (poput *negativne eksponencijalne krivulje* ili *glatke kubne krivulje*), a potom izračunavanje srednje vrijednosti svih individualnih uzoraka za izradu glavne kronologije (Speer, 2010; Hughes i sur., 2011). Na taj način dobiveni su referentni dendrokronološki nizovi korišteni za datiranje.

$R\text{-bar}$  i EPS spadaju u osnovne statističke pokazatelje u ARSTAN-u koji pokazuju ispravnost veličine uzorka za dobivanje stabilnog i jasnog signala u svim klimatološkim istraživanjima (Butler i sur. 2013).

$R\text{-bar}$  (ili *running r-bar*) je prosječni korelacijski koeficijent između pojedinih uzoraka koji se koriste za izračun kvalitete signala kroz cijelu kronologiju, tzv. EPS (Goršić, 2013).

EPS (*expressed population signal*) je statistička mjera koja ukazuje na razinu zajedničkog signala među uzorcima korištenim za konstrukciju kronologije. Za konačan prikaz funkcije klimatskog odaziva hrasta lužnjaka korišten je R program



baziran na R programskom jeziku koji se koristi za integralno razvijanje statističkog računanja, grafiku, linearno i nelinearno modeliranje, analizu vremenskih nizova i sl. Referentna rezidualna kronologija iz ARSTAN-a mora biti uspoređena s klimatskim podacima za potpuno razumijevanje utjecaja klime na značajke godina (Zang i Biondi, 2012).

## 4. REZULTATI I RASPRAVA

### 4.1. Statistička provjera međusobne podudarnosti uzoraka u COFECHA-i

Statistička analiza u COFECHA-i provedena je na 42 uzorka hrasta lužnjaka, osnovne kronologije dužine 270 godina (slika 4.1). Koristeći tzv. fleksibilnu (*32 year cubic smoothing spline 50% cutoff*) krivulju za filtriranje podataka glavne kronologije i autoregresivnim modelom sa rezidualnim podacima, dobivene su odlične korelacije 50-godišnjih segmenata (s 25-godišnjim pomakom) individualnih serija uzoraka s glavnom kronologijom u razdoblju od 1746.-2015.

```

Dendrochronology Program Library          Run PRASN Program COF 11:35 Thu 14 Jul 2016 Page 1
PROGRAM COFECHA                          Version 6.06P 29782
-----
QUALITY CONTROL AND DATING CHECK OF TREE-RING MEASUREMENTS

Title of run:      Prasnik
File of DATED series:  Krono.rwl

CONTENTS:
Part 1: Title page, options selected, summary, absent rings by series
Part 2: Histogram of time spans
Part 3: Master series with sample depth and absent rings by year
Part 4: Bar plot of Master Dating Series
Part 5: Correlation by segment of each series with Master
Part 6: Potential problems: low correlation, divergent year-to-year changes, absent rings, outliers
Part 7: Descriptive statistics

RUN CONTROL OPTIONS SELECTED          VALUE
1 Cubic smoothing spline 50% wavelength cutoff for filtering          32 years
2 Segments examined are                      50 years lagged successively by 25 years
3 Autoregressive model applied              A Residuals are used in master dating series and testing
4 Series transformed to logarithms          Y Each series log-transformed for master dating series and testing
5 CORRELATION is Pearson (parametric, quantitative)
Critical correlation, 99% confidence level .3281
6 Master dating series saved                N
7 Ring measurements listed                  N
8 Parts printed                            1234567
9 Absent rings are omitted from master series and segment correlations (Y)

Time span of Master dating series is 1746 to 2015 270 years
Continuous time span is 1746 to 2015 270 years
Portion with two or more series is 1748 to 2015 268 years

*****
*C* Number of dated series 42 *C*
*Q* Master series 1746 2015 270 yrs *Q*
*F* Total rings in all series 8699 *F*
*E* Total dated rings checked 8697 *E*
*C* Series intercorrelation .612 *C*
*H* Average mean sensitivity .203 *H*
*A* Segments, possible problems 10 *A*
*** Mean length of series 207.1 ***
*****

```

Slika 4.1 Pregled osnovnih parametara COFECHA analize (COFECHA)

Correlations of 50-year dated segments, lagged 25 years  
 Flags: A = correlation under .3281 but highest as dated; B = correlation higher at other than dated position

Seq	Series	Time_span	1725 1774	1750 1799	1775 1824	1800 1849	1825 1874	1850 1899	1875 1924	1900 1949	1925 1974	1950 1999	1975 2024
1	0000nn	1763 2015		.68	.76	.71	.62	.70	.78	.78	.76	.66	.59
2	P-5-12	1796 1967		.76	.74	.83	.85	.68	.70	.67			
3	P10-60	1834 1981				.72	.76	.59	.61	.78	.60		
4	PR9-64	1771 2015		.37	.44	.40	.59	.65	.58	.59	.53	.41	.39
5	P2-129	1885 2006						.48	.49	.56	.49	.39	
6	P2-131	1791 2014			.74	.67	.70	.78	.59	.46	.40	.45	.44
7	P5-47R	1827 2003				.77	.82	.77	.57	.55	.19B	.14B	
8	OP5-64	1832 2015				.75	.84	.62	.63	.79	.70	.73	
9	P6-27R	1810 2015				.67	.71	.57	.42	.51	.52	.45	.41
10	P7-172	1778 2015			.83	.69	.72	.69	.55	.67	.64	.43	.46
11	P7-70R	1746 2015	.21B	.22A	.76	.77	.78	.86	.74	.71	.72	.64	.77
12	OP9-12	1898 2015							.48	.48	.62	.55	.54
13	P9-69R	1879 2014							.54	.45	.52	.43	.37
14	OPR1-6	1768 2015		.73	.81	.83	.87	.85	.61	.52	.67	.52	.53
15	PR1-68	1781 2015			.88	.85	.80	.78	.79	.74	.72	.66	.60
16	PR1-76	1768 2015		.62	.68	.57	.61	.70	.60	.61	.75	.67	.50
17	PR10-3	1810 2015				.71	.83	.86	.77	.76	.68	.35	.39
18	PR10-4	1759 2015		.34	.36	.53	.85	.89	.71	.66	.74	.58	.65
19	PR10-5	1778 2015			.73	.66	.80	.87	.84	.83	.81	.72	.74
20	PR10-9	1884 2014							.61	.58	.46	.53	.35
21	PR2-11	1769 2015		.36B	.49	.50	.56	.63	.60	.55	.49	.46	.43
22	PR3-10	1843 2015					.61	.71	.57	.60	.64	.57	.61
23	PR3-10	1826 2015					.71	.67	.59	.68	.75	.63	.63
24	PR3-11	1833 2015					.60	.56	.57	.68	.64	.57	.60
25	PR3-12	1825 2015					.57	.54	.38	.43	.46	.36	.46
26	PR3-30	1839 2015					.63	.73	.67	.64	.60	.51	.39
27	PR3-33	1848 2015					.51	.50	.45	.64	.59	.46	.50
28	PR3-84	1785 2013			.40	.31B	.58	.56	.57	.67	.64	.49	.46
29	PR4-11	1765 2015		.68	.84	.74	.83	.87	.78	.83	.76	.55	.52
30	PR4-12	1838 2015					.79	.84	.81	.71	.37	.31A	.38
31	PR5-10	1846 2015					.83	.86	.74	.71	.75	.54	.62
32	PR5-15	1767 2015		.75	.80	.77	.81	.68	.49	.74	.78	.53	.40
33	PR5-39	1758 2015		.66	.75	.67	.69	.78	.86	.74	.73	.65	.61
34	PR5-99	1763 2015		.39	.42	.53	.73	.89	.78	.77	.69	.63	.68
35	PR5-mu	1785 1964			.79	.74	.78	.77	.50	.44	.51		
36	PR5-su	1817 1983				.71	.72	.60	.50	.58	.59	.50	
37	PR7-14	1783 2015			.72	.66	.58	.60	.56	.57	.69	.57	.48
38	PR7-70	1762 2015		.56	.69	.70	.76	.82	.84	.84	.70	.58	.64
39	PR8-11	1748 2015	.30A	.30A	.52	.68	.71	.67	.57	.62	.73	.63	.63
40	PR8-69	1798 2015			.69	.66	.69	.72	.62	.51	.64	.55	.49
41	PR8-75	1818 1968				.61	.64	.78	.64	.57	.56		
42	OPR9-1	1757 2011		.32A	.52	.55	.70	.74	.74	.73	.69	.61	.48
AV	segment correlation		.26	.50	.67	.65	.71	.74	.63	.63	.64	.53	.51

Slika 4.2 Prikaz korelacije 50-godišnjih segmenata sa referentnom kronologijom (COFECHA)

Kompjutorski program COFECHA uspostavlja korelaciju među uzorcima dijeljenjem širine godina individualnih uzoraka u manje segmente od 50 godina koje potom uspoređuje sa istim kalendarskim segmentom prosjeka svih uzoraka proučavane kronologije. Kao rezultat dobivaju se podaci o eventualnim pogreškama pri izmjeri uzoraka kao i općeniti uvid u podatke o duljini dobivene kronologije, osjetljivosti kronologije te opisni statistički podaci o kronologiji (slika 4.2). U slučaju da je utvrđena pogreška u mjerenju, uzorak se mora ponovno izmjeriti, dok oni uzorci koji ne odgovaraju populaciji ni nakon ponovljenog mjerenja, se izbacuju iz daljnje analize. Osim pogreške prilikom mjerenja, razlozi nekompatibilnosti uzoraka mogu biti u mehaničkim oštećenjima, uraslim granama, oštećenjima od biotskih (gradacija kukaca) ili abiotskih (mraz, grom) čimbenika. (Goršić 2013).




Slika 4.3 Primjer uzorka s uraslom granom  
(preuzeto od Goršić, 2013)

#### 4.2. ARSTAN – veličina uzoraka, EPS i *RUNNING R-BAR*

Stabla u mladosti intenzivno debljinski prirašćuju (juvenilni rast), no taj rast se postepeno tokom života usporava. Ako uzmemo u obzir specifične zahtjeve i uvjete stabala koja rastu u sklopu (kompeticija, ograničeni utjecaj određenih klimatskih faktora poput svjetla) i stabala koja rastu na osami (izostaje kompeticija, puni užitak svjetla, no i nezaštićenost stabala od ekstremnih utjecaja kiše, sunca i drugih faktora), transformacijskom metodom se nastoji ukloniti varijabilnost debljinskog prirasta stabala u sastojini koja nije klimatski uvjetovana te ukloniti ekstremne širine godova stabala u ranoj fazi njihovog rasta (Goršić 2013.).

U Arstanu se standardizacijskim funkcijama uklanjaju individualni trendovi vezani uz prirast pojedinih stabala. Oni se svode na „zajedničku“ mjeru definiranu sa indeksnim vrijednostima koje smanjuju varijabilnost u širini godova, uz korištenje rezidualnih podataka.

Većina slika iz ovog podpoglavlja ispisi su iz programa ARSTAN, a za ostale je posebno naznačeno. Pri tome su na x-osi kalendarske godine, a na y-osi *measurements* predstavljaju širine godova, *indices* – vrijednost indeksa i *samples* – veličinu uzorka.




Slika 4.4 Prikaz izjednačene krivulje prirasta  
(preuzeto iz Fritts 1976)

Dendrokronološkom analizom napravljena je lokalna kronologija za lokaciju Prašnik. Podaci širine godova transformirani su u programu ARSTAN (Cook 1985). Osim transformirane kronologije koja se koristi za datiranje, kreirana je i standardna kronologija uklapanjem spline funkcije sa krutošću 2/3 (67%) duljine kronologije. Rezidualna kronologija korištena je za dendroklimatološke analize.

Koristeći fleksibilnu (*spline*) krivulju s 50%-tnim odrezom, uz transformaciju podataka koristeći tzv. *adaptive power transformation* (Cook i Peters, 1997.) tehniku za stabiliziranje varijance osnovne kronologije, te uz *r-bar* s 30-ogodišnjim segmentom promatranja i pomakom za jednu godinu (*29-year overlap*), u grafičkom je obliku dobiven pregled referentnih kronologija u osnovnom (*raw*) i rezidualnom (*residual*) obliku (slika 4.5), kao i pregled statističkih pokazatelja *rbar-a* i *EPS-a* te veličine uzorka (slika 4.6).


U čitavom razdoblju osnovne kronologije (Slika 4.5 gore) može se vidjeti jedan tipičan izgled sinusoidne krivulje.



Slika 4.5 Prikaz osnovnog dendrokronološkog niza (gore), rezidualnog kronološkog niza (sredina) i veličine uzorka (dno) za lokaciju prašume Prašnik

Rezidualna kronologija (slika 4.5 sredina) uklanja autokorelacije regresivnim modelima te su vrijednosti širina godova svedeni na indeksne vrijednosti (prosječni indeks=1), uklonjena je varijabilnost u širinama godova te ostali trendovi individualnih uzoraka.

Za rezidualnu kronologiju u razdoblju od 1780.-2015. prosječna vrijednost EPS-a nam pokazuje da je zajedniči signal dovoljno kvalitetan za testiranje utjecaja klimatskih čimbenika budući da ta vrijednost prelazi empirički prihvaćenu granicu od 0,85 za pouzdano korištenje kronologije u dendroklimatološkim istraživanjima.




Slika 4.6 Grafički prikaz rbar-a (gore) i EPS (dolje) za Prašnik.

U dendroklimatološkim istraživanjima, empirički prihvaćena granična vrijednost EPS-a (0.85) predstavlja granicu ispod koje promatrana kronologija počinje gubiti koherentni skupni signal i počinje dominirati signal pojedinačnih stabala (Clark i Speer, unpublished). Kao takva, kronologija se može koristiti za datiranje (npr. u dendroarheološkim istraživanjima), međutim ostaje nepouzdana za kalibraciju s klimatskim podacima i interpretaciju u svrhe rekonstrukcije klime (Speer, 2010.). Kako bi se uklonila mogućnost autokorelacije uzoraka, odabire se jedna od standardizacijskih metoda iz postavki programa ARSTAN.

Rezidualne kronologije predstavljaju prosječnu vrijednost za svaku kalendarsku godinu, a dobivaju se kao razlika vrijednosti prosječne širine godova svakog pojedinačnog uzorka i vrijednosti dobivene implementiranjem odabranog standardizacijskog modela krivulje u programu ARSTAN. Za razliku od standardne kronologije (slika 4.5 gore), u rezidualnoj kronologiji (slika 4.5 sredina) uklonjena je



moćnost autokorelacije uzoraka upravo jednom od standardizacijskih metoda odabranom u postavkama programa.




Slika 4.7 Grafički prikaz rbar-a (gore) i EPS (dolje) pokazatelja statističke analize u rezidualnoj kronologiji (ARSTAN)

Prosječna korelacija između uzoraka upućuje na dobar zajednički klimatski signal u uzorcima. Nešto niža vrijednost EPS-a na početku kronologije rezultat je manjeg broja uzoraka koji zahvaćaju početak kronologije.


### 4.3. Klimatski odziv hrasta lužnjaka prema temperaturi i oborinama

Klimatski odziv analiziran je prema rezidualnoj referentnoj kronologiji u razdoblju od 113 godina (1901. – 2014.) sa prikazanim koeficijentima korelacije (*response coefficient*) po mjesecima (*months*). Zasebno je prikazan grafovima za temperaturu i oborine (slika 4.8 i 4.9). Statistički značajna ovisnost prikazana je tamnim pravokutnicima.



Slika 4.8 Prikaz koeficijenata korelacije prirasta i temperature





Slika 4.9 Prikaz koeficijenata korelacije prirasta i oborina

Statistički značajan negativan utjecaj temperature vidljiv je u travnju i srpnju. Drugim riječima, visoke temperature tijekom tih mjeseci negativno djeluju na debljinski prirast hrastovih stabala u Prašniku. Na temelju rezultata istraživanja vidljiv je statistički značajan pozitivan utjecaj oborina za razdoblje siječanj – travanj, na prirast hrastovih stabala tekuće godne.

U proljeće kada ekološki uvjeti postanu povoljni, hrast lužnjak aktivira kambij. Aktivacijom kambija započinje i njegov debljinski prirast. Debljinski prirast većine stabala kod nas počinje krajem travnja, a završava u listopadu (Klepac 1963). Debljinski prirast je ispočetka nešto intenzivniji dok kasnije usporava do konačnog prestanka u jesen. Debljinski prirast se očituje stvaranjem goda. Prvo se stvara rano drvo tj. provodni elementi širokih lumena. Prema Goršiću (2013), u trenutku kada lužnjak ima potpuno formirane listove, istovremeno ima formiran samo prvi red provodnih elemenata ranog drva. Ukoliko u tom razdoblju vladaju povoljni stanišni uvjeti (povoljne oborine i temperatura), pozitivno će se odraziti na debljinski prirast lužnjakovih stabala.

Prema podacima Meteoblue-a, koji prati trend klime u zadnjih par desetljeća, možemo iščitati trend koji pokazuje da Okučani (lokalitet uz Prašnik) imaju više od 18

dana u mjesecu travnju sa temperaturom višom od 15 °C. Ako se tome pridoda više od 10 dana sa jačinom vjetra većom od 19 km/h, pretpostavka je da je tlo na površini ispucalo što pokazuje da ide u smjeru isušivanja, ali su donji slojevi možda vlažni. Navedeni podaci predstavljaju trend što ne znači da odgovaraju za svaku pojedinu godinu te ne možemo sa sigurnošću tvrditi da to utječe na prirast stabala.


Isušeno i ispucalo tlo nije nerjetka pojava u travnju u nizinskim lokalitetima gdje uspjeva hrast lužnjak. Već je ranije spomenuto da u to vrijeme lužnjak počinje sa svojim debljinskim prirastom a razlog tome je kombinacija visoke temperature te pretpostavka niskog vodostaja koji imaju negativan utjecaj.

Važno je spomenuti i prokopani kanal Slobostina, koji presijeca Prašnik te koji je vjerojatno doprinio do smanjenja razine podzemne vode. Svi navedeni čimbenici doveli su do slabijeg debljinskog prirašćivanja hrasta lužnjaka. Sličnu situaciju navodi i Goršić (2013), gdje su na lužnjak sa području Cerne travanjske temperature negativno utjecale na debljinski prirast stabala. Tome je vjerojatno doprinijela i činjenica da je to područje dosta ispresijecano mrežom vodotoka.

Također, rečeno je da je Prašnik prostorni šumski kompleks čije su stanište, vegetacija i smjesa drveća podložni isključivo prirodnim utjecajima, što ga kao takvog čini prašumom u kojoj prevladavaju jako stara stabla. Stabla tako velikih dimenzija imaju i krošnje velikih dimenzija koje nesmetane od susjednih stabala apsorbiraju sunčevu svjetlost. Naime, međusobna konkurencija među takvim orijaškim primjercima je davno prestala te se svaki od njih izborio za svoje mjesto u sastojini. U prva četiri mjeseca, kad su oborine pokazale statistički pozitivno značajan utjecaj na prirast lužnjaka, vrlo vjerojatno je došlo do rasta razine podzemne vode. Zasigurno su tu i neki drugi ekološki čimbenici koji su tome pridonijeli, primjerice duljina korijenskog sustava, a naročito žile srčanice može varirati kod jedinki na gredi kod kojih je korjenje nešto duže od onih u nizi kojima je podzemna voda pristupačnija (Prpić, 1996). Korelacija prirasta i temperature u srpnju pokazala je statistički značajan negativan utjecaj što je i bilo očekivano zbog velikih vrućina (osam dana temperature veće od 30°C u kombinaciji sa skoro 19 suhih dana).

Idući od zapada prema istoku Hrvatske, vrlo je mala razlika temperaturnog gradijenta, nemamo ekstremnih oscilacija, dok je oborinska oscilacija više lokalnog karaktera. Moguće je da su lužnjakova stabla u svojim 250-300 godina postojanja razvila određenu prilagodbu na temperaturu koja se nije znatnije mijenjala tijekom godina

dok se prilagodba na oborina drugačije odrazila kod mlađih stabala nego kod onih starijih (u starijoj dobi nemaju dobru sposobnost prilagodbe) koje su jako varirajuće među lokalitetima (vidi sliku 4.10), te nema uvriježenosti u njihovoj pojavi. Stoga su oborine čimbenik koji imaju značajnog utjecaja na debljinski prirast lužnjakovih stabala.



Slika 4.10 Usporedba oborina i temperatura: Vinkovci (gore) i Nova Gradiška (dolje)

Istražujući sastojine jele, Božić i sur. (2006) došli su do rezultata gdje su intenzivniji zahvati u sastojini doveli do povećanja radijalnog prirasta. Nakon sječe, sklop se

otvorio, dogodio se veći priljev svjetla u sastojinu koji je pozitivno utjecao na radijalni prirast. Iako se radilo o gospodarskoj šumi, slična situacija se može odvijati i u prašumi. Pošto su stabla jako stara, često smanjenog vitaliteta, ona svakodnevno odumiru te za sobom ostavljaju i velike progale, veliku prazninu u sklopu zbog velikih dimenzija krošanja.

## 5. ZAKLJUČAK

Relativno visoke temperature u travnju u eventualnoj kombinaciji sa mogućim niskim vodostajem Save imale su statistički značajan negativan utjecaj na debljinski prirast lužnjakovih stabala. Također, visoke temperature u srpnju na isti su način utjecale na debljinski prirast. Statistički značajan pozitivan utjecaj na debljinski prirast lužnjakovih stabala pokazale su oborine od siječnja do travnja, koje su jako bitne da tlo bude zasićeno vodom.

Prašnik je dugo bio izoliran ekosustav te se tim područjem nije gospodarilo. Usprkos toj činjenici ne možemo reći da na njega nije bilo nikakvog antropogenog utjecaja, te bi također bilo pogrešno reći da je on ekosustav izoliran od čovjekovog utjecaja (onečišćenje zraka i vode, hidromeliorativni zahvati) (Anić, 2004). Za budućnost nam može poslužiti za provođenje novih istraživanja te usporedba sa ostalim gospodarenim lužnjakovim sastojinama s ciljem boljeg razumijevanja utjecaja raznih stanišnih i drugih čimbenika na debljinski prirast hrasta lužnjaka.

## 6. LITERATURA

- 1) Anić, I. 2004. Prašume i njihovo značenje za gospodarenje šumama u Hrvatskoj. Glasnik zaštite bilja
- 2) Bašić, F. 2013. The Soils of Croatia, World Soil Book Series, International Union of Soil Sciences. In: Hartemink, A.E. (ed), Springer Verlag, 142-144, 179 p. bazena. Rad. Šumar. Inst. 31 (1-2), 37-89, Jasterbarsko
- 3) Becker, M., 1991. Impact of climate, soil and silviculture on forest growth and yield. U: Landmann, G. (ur.), French research into forest decline. Ecole nationale du Génie rural, des Eaux et des Forêts, 23-38, Nancy.
- 4) Biondi, F. i Qedan, F. 2008. A Theory-driven approach to Tree-ring Standardization: Defining the Biological Trend from Expected Basial Area Increment. Tree-Ring Research, Vol. 64(2),pp. 81–96
- 5) Biondi, F. i Qedan, F. 2008. A Theory-driven approach to Tree-ring Standardization: Defining the Biological Trend from Expected Basial Area Increment. Tree-Ring Research, Vol. 64(2),pp. 81–96
- 6) Bobinac, M., Andrašev, S., 2009. Učinci uzgojnih mjera u devitaliziranoj srednjodobnoj sastojini lužnjaka (*Quercus robur* L.) na černozeu u Vojvodini. Šumarski list 133 (9–10), 513-526.
- 7) Bogunović, M., Vidaček, Ž., Racz, Z., Husnjak, S., Špoljar, A., Sraka, M. FAO/Unesco Croatian soil map, small scale 1:1000000, University of Zagreb, Faculty of Agriculture, project Monitoring Agriculture with Remote Sensing (1998).
- 8) Božić, M., 2003. Utjecaj stanišnih i sastojinskih elemenata na prirast obične jele (*Abies alba* Mill.) u jelovim sastojinama na kršu u Hrvatskoj. Disertacija, Sveučilište u Zagrebu, Šumarski fakultet 190 str., Zagreb.
- 9) Buser, S., Ramovs, A., Drovenik, M. & Pleničar, M. 1989. Geological setting of Slovenia. In: Encyclopedia of Slovenia, 3rd edn. Mladinska knjiga, Ljubljana, 195–203.
- 10) Butler, PG i sur. 2013). EPS, rbar and associated statistics. U: Butler, Paul G; Wanamaker, Alan D; Scourse, James D; Richardson, Christopher A; Reynolds, David J (2013): Variability of marine climate on the North Icelandic Shelf in a

- 1357-year proxy archive based on growth increments in the bivalve *Arctica islandica*. *Palaeogeography, Palaeoclimatology, Palaeoecology*, 373, 141-151
- 11) Christiansen, B. 2011. Reconstructing the NH mean temperature can underestimation of trends and variability be avoided? *Journal of Climate* 24, 674-692
  - 12) Cook, E.R. 1985. A time series analysis approach to tree-ring standardization. PhD dissertation, University of Arizona, Tucson, 171pp.
  - 13) Cook, E.R., i Holmes, R.L. 1986. Users manual for program ARSTAN. U: Holmes, R.L., Adams, R.K., i Fritts, H.C., eds, *Tree-Ring Chronologies of Western North America, Chronology Series Vol. 6*. Laboratory of Tree-Ring Research, University of Arizona, Tucson. pp. 50-56
  - 14) Cook, E.R., i Krusic, P.J. 2005. Program ARSTAN: A Tree-Ring Standardization Program Based on Detrending and Autoregressive Time Series Modeling, with Interactive Graphics. Tree-Ring Laboratory Lamont Doherty Earth Observatory of Columbia University, Palisades, NY
  - 15) Cook, E.R., i Peters, 1997. Calculating unbiased tree-ring indices for the study of climatic and environmental change. *Holocene* 7: 361-370.
  - 16) Cook, E.R., Kairiukstis, L.A. 1990. *Methods of Dendrochronology: Applications in the Environmental Sciences*. Kluwer Academic Publishers, Dordrecht, Netherlands. 394. str.
  - 17) Dekanić, I., 1975. Utjecaj visine i oscilacije nivoa podzemnih voda za sušenje hrasta
  - 18) Fritts, H.C. 1969. Elementary Probability for Biologists. *Ecology*, Volume 50, Issue 6
  - 19) Fritts, H.C. 1976. *Tree Rings and Climate*. Academic Press, New York. 567 pp.
  - 20) Grissino-Mayer, H.D., Henri, D. 2001. Evaluating crossdating accuracy: a manual and tutorial for the computer program COFECHA. *Tree-Ring Research* 57(2): 205-221
  - 21) Halamić, J. & Miko, S. (eds) 2009: *Geochemical Atlas of the Republic of Croatia-Croatian Geological Survey*, Zagreb, 87 p.
  - 22) Holmes, R.L. 1983. Computer-assisted quality control in tree-ring dating and measurement. *Tree-Ring Bulletin* 43:69-785

- 23) Hughes, M.K., Swetnam, T.W., i Diaz, H.F. 2011. Dendroclimatology: Progress and Prospects. Laboratory of Tree-Ring Research, University of Arizona, Tucson
- 24) Husnjak, S. 2014. Sistematika tala Hrvatske (*Systematics of soils in Croatia*), Hrvatska sveučilišna naklada, Tiskara Zelina d.d., Zagreb, 373 p. (*in Croatian*)
- 25) Kajba, D., 2006. Klimatske promjene i genetska raznolikost šumskog drveća: Utjecaj na održivo gospodarenja europskih šuma, Pariz, Francuska 15.-16. ožujak 2006.godine, Šum. list 3-4:149-150.
- 26) Klepac, D., 1959. Izračunavanje gubitka na prirastu u sastojinama koje je napao gubar (*Lymantria dispar*). Šumarski list 83 (8–9): 280–290.
- 27) Lukić, N., Galić, Ž., Čavlović, J., 2001. Dendrokronološka analiza debljinskog prirasta lužnjakovih sastojina u šumama Žutica i Opeke. Znanost u potrajnom gospodarenju hrvatskim šumama: znanstvena knjiga 435-445 Zagreb. lužnjaka (*Quercus robur* L.) Šumarski list 99 (7-10), 267-280.
- 28) Marcais, B., Desprez-Loustau, M., L., 2012. European oak powdery mildew: impact on trees, effects of enviromental factors, and potential effects of climate change. Ann. of. For. Science.
- 29) Matić, S., 2000. Oak forests (*Quercus* sp.) in Croatia. Glas. Šum. Pokuse, Zagreb, 37, 5-13.
- 30) Mayer, B., 1996. Hidropedološki odnosi na području nizinskih šuma pokupskog
- 31) Mesić Kiš, I., Karaica, B., Medunić, G., Romić, M., Šabarić, J., Balen, D., Šoštariko, K., 2016. Soil, bark and leaf trace metal loads related to the war legacy (The Prašnik rainforest, Croatia, The Mining-Geology-Petroleum Engineering Bulletin.
- 32) Milković, I., 1998. Utjecaj prorede na vrijednosni prirast hrasta lužnjaka, Magistarski rad. Zagreb, Šumarski fakultet, 110 str.
- 33) Prpić, B., 1996. Propadanje šuma hrasta lužnjaka, In: Klepac, D. (ed), Hrast lužnjak (*Quercus robur* L.) u Hrvatskoj, HAZU and Hrvatske šume Zagreb, 273-298.
- 34) Rauš Đ., Prpić B., Matić S., Vranković A., 1979. Rezervati šumske vegetacije Prašnik i Muški bunar. Studija ekološko-uzgojnih osobina. Š. G. "Josip Kozarac" Nova Gradiška.



- 35) Anić I, Mikac, S., 2008. Prirodno pomlađivanje hrasta lužnjaka (*Quercus robur* L.) na malim površinama. Znanstveno savjetovanje: šume hrasta lužnjaka u promjenjenim stanišnim i gospodarskim uvjetima.
- 36) Božić, M., Čavlović, J., Teslak, K., 2006: Modeliranje prirasta jelovih stabala na temelju sastojinskih čimbenika. Glasnik za šumske pokuse (posebno izdanje 5), 443 – 454.
- 37) Čavlović, J., Božić, M., Teslak, K., 2009. Ophodnja i obrast pri planiranju gospodarenja šumama hrasta lužnjaka u uvjetima narušene strukture sastojina. Zbornik radova sa znanstvenog skupa „Šume hrasta lužnjaka u promjenjenim stanišnim i gospodarskim uvjetima“, HAZU, 23-37.
- 38) Čavlović, J., Božić, M., Teslak, K., 2006: Mogućnost uspostave potrajnoga gospodarenja šumama hrasta u budućim gospodarskim razdobljima. Glasnik za šumarske pokuse (posebno izdanje 5) 419 – 431.
- 39) Kajba., D., Hrašovec, B., 2008. Klonske sjemenske plantaže hrasta lužnjaka (*Quercus robur* L.) i njihova uloga u očuvanju genofonda u uvjetima klimatskih promjena i povećanih rizika od napada šumskih kukaca. Znanstveno savjetovanje: šume hrasta lužnjaka u promjenjenim stanišnim i gospodarskim uvjetima.
- 40) Matić, S., 2008. Gospodarenje šumama hrasta lužnjaka (*Quercus robur* L.) u promjenjenim stanišnim i strukturnim uvjetima. Znanstveno savjetovanje: šume hrasta lužnjaka u promjenjenim stanišnim i gospodarskim uvjetima.
- 41) Pilaš, I., 2008. Režim podzemnih voda i odumiranje šuma hrasta lužnjaka u Hrvatskoj – naznaka globalnih klimatskih promjena. Znanstveno savjetovanje: šume hrasta lužnjaka u promjenjenim stanišnim i gospodarskim uvjetima.
- 42) Prpić, B. 1972. Neka nasljedna svojstva biljaka hrasta lužnjaka (*Quercus robur* L.) iz vlažnoga i umjereno vlažnoga šumskog ekosustava. Znanstveno savjetovanje: šume hrasta lužnjaka u promjenjenim stanišnim i gospodarskim uvjetima.
- 43) Prpić, B., 1996. Propadanje šuma hrasta lužnjaka, In: Klepac, D. (ed), Hrast lužnjak (*Quercus robur* L.) u Hrvatskoj, HAZU and Hrvatske šume Zagreb, 273-298.
- 44) Rinn, F. 2003. TSAP-Win user reference. Heidelberg, Germany.

- 45) Schweingruber, F.H. 1988. Tree Rings: Basics and Applications of Dendrochronology. D Reidel Publishing Co., Dordrecht, Nizozemska. 276 pp.
- 46) Speer, J.H. 2010. Fundamentals of Tree Ring Research. The University of Arizona Press. web
- 47) Šikić, K., Basch, O. & Šimunić, A. 1979. Geology of Zagreb Sheet (L38-80), Basic geological map of Yugoslavia, 1:100000, Institute of Geology, Zagreb, Beograd (Federal institute of Geology) (in Croat., Engl. Summary).
- 48) Šparica, M., Buzaljko, R. & Jovanović, Č. 1984. Geology of Nova Gradiška Sheet (L33-107). Basic geological map of Yugoslavia, 1:100000. Institute of Geology, Zagreb, Institute of Geology, Sarajevo, Beograd (Federal institute of Geology) (in Croat.).
- 49) Tikvić, I., Pernar, N., Seletković, Z., Ugarković, D., Mikac, S., 2008. Promjene hidroloških uvjeta u nizinskim šumskim ekosustavima i mogućnost njihovog unaprijeđenja. Znanstveno savjetovanje: šume hrasta lužnjaka u promjenjenim stanišnim i gospodarskim uvjetima.
- 50) Trinajstić, I., 1996. Taksonomska problematika hrasta lužnjaka u Hrvatskoj, U: Klepac, D. (ur.), Hrast lužnjak u Hrvatskoj. HAZU Centar za znanstveni rad Vinkovci i HŠ p.o., Zagreb, 96-101.
- 51) Vajda, Z., 1948. Koji su uzroci sušenju hrastovih posavskih i donjo-podravskih šuma? Šumarski list, 72 (4), 105-113
- 52) Webb, G.E. 1983. Tree rings and Telescopes, University of Arizona, Tucson
- Trouet, V., von Oldenborgh, G.J. 2013. CNMI Climate Explorer: A web-based research tool for high-resolution paleoclimatology. Tree-ring Research, Vol. 69(1), 2013, pp. 3–13

#### Web izvori:

- 1) <http://www.lickosenjska.com/> (Prašuma Prašnik)
- 2) [http://www.novagra.hr/index.php?option=com\\_content&view=article&id=505:pranik-imuki-bunar-neotkriveni-rezervati-umske-vegetacije&catid=70:turizamugostiteljstvo&Itemid=44](http://www.novagra.hr/index.php?option=com_content&view=article&id=505:pranik-imuki-bunar-neotkriveni-rezervati-umske-vegetacije&catid=70:turizamugostiteljstvo&Itemid=44) (Slika 1.2)
- 3) [www.euforgen.org/distribution\\_maps.html](http://www.euforgen.org/distribution_maps.html) (slika 1.4)
- 4) [www.wissenschaft-online.de/abo/lexikon/biok/466](http://www.wissenschaft-online.de/abo/lexikon/biok/466) (slika 1.6)
- 5) <http://www.cru.uea.ac.uk/> (slika 1.7)
- 6) <https://climexp.knmi.nl/start.cgi?id=someone@somewhere> (KNMI Climate Explorer)

- 7) <http://www.cybis.se/forfun/dendro/> (CDendro and CooRecorder)
- 8) <http://www.meteoblue.com> (slika 4.10)
- 9) [http://www.mppi.hr/UserDocsImages/10\\_Prilog5\\_sava\\_stanista2\\_2.pdf](http://www.mppi.hr/UserDocsImages/10_Prilog5_sava_stanista2_2.pdf)